

모듈라 신경망을 이용한 자동차 번호판 문자인식

Character Recognition of Vehicle Number Plate using Modular Neural Network

박창석* · 김병만* · 서병훈* · 이광호**

Chang Seok Park, Byeong Man Kim, Byung Hoon Seo and KwangHo Lee

*금오공과대학교 소프트웨어공학과

**목포대학교 컴퓨터교육과

요 약

최근, 분류기 쪽에서는 모듈라 학습을 이용한 방법들에 대해서 상당한 관심이 모아지고 있다. 분할 및 합병 개념에 바탕을 둔 모듈라 학습 방법이 복잡한 문제를 해결함에 있어서 학습 질 측면이나 학습 속도 면에서 단일 분류기에 비해 좋은 결과를 보이고 있고, 인공신경망을 이용한 분류 방법 쪽에서도 이러한 연구들이 이루어지고 있다. 본 논문에서는 자동차 번호판 인식을 위한 간단한 형태의 모듈라 신경망을 제안하고 모듈라 신경망 구성 시, 특징 벡터 클러스터링 방법에 따른 모듈라 신경망의 성능을 평가하였다. K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터를 그룹핑하는 방법과 본 논문에서 제안한 알고리즘을 사용하여 유사하지 않는 특징 벡터들을 그룹핑하는 방법 각각을 구현하여 실험하였다. 실험결과, 유사하지 않는 특징 벡터들로 모듈라 신경망을 구성할 경우가 그렇지 않은 경우보다 좋은 인식 결과를 보였다.

Abstract

Recently, the modular learning are very popular and receive much attention for pattern classification. The modular learning method based on the "divide and conquer" strategy can not only solve the complex problems, but also reach a better result than a single classifier's on the learning quality and speed. In the neural network area, some researches that take the modular learning approach also have been made to improve classification performance.

In this paper, we propose a simple modular neural network for characters recognition of vehicle number plate and evaluate its performance on the clustering methods of feature vectors used in constructing subnetworks. We implement two clustering method, one is grouping similar feature vectors by K-means clustering algorithm, the other grouping unsimilar feature vectors by our proposed algorithm. The experiment result shows that our algorithm achieves much better performance.

Key Words : 모듈라 신경망, 클러스터링, 번호판 인식, 모듈라 학습

1. 서 론

국내의 자동차 번호판 문자 인식에 관한 연구는 크게 번호판 영역 추출 부분과 인식 부분으로 나뉘어 연구되어 오고 있다. 번호판 영역 추출에서의 선행 연구들은 칼라 명암도 변화를 이용하여 번호판 영역을 추출하는 방법[1], 소벨 연산과 Hough 변환에 의한 방법[2,3], 단일 색상 정보에 의한 방법[4,5], 복합 색상 정보에 의한 방법[6] 등이 있고, 인식에서 선행된 연구로는 번호판 영역에서 추출된 개별 문자에 신경망을 적용한 방법[7,8,9]과 원형정합 알고리즘, 세션화 알고리즘, 벡터 알고리즘 등 여러 가지 알고리즘을 병행 적용한 방법[10] 등이 있다. 본 논문에서는 자동차 번호판 인식 과정에서 문자 인식 부분에 초점을 맞춘다.

일반적으로 신경망을 이용한 문자인식에서는 ART2와 같은 인공신경망 모델을 선택할 수도 있지만 다층퍼셉트론이 기본적인 인공신경망 모델이고 구현이 용이한 관계로 본 논문에서는 이 모델을 선택하였다. 다층 퍼셉트론을 자동차 번호판 문자인식에 사용할 경우 자동차 번호판에서 올 수 있는 패턴의 수가 상당히 많아지는데 이 때문에 백프로퍼게이션 학습 알고리즘에 문제인 지역 최소값에 빠지거나 제대로 학습이 되지 않아 인식을 저하를 초래한다. 따라서 본 논문에서는 이를 해결하고자 신경망에 모듈라 개념을 도입한다.

최근 분류기 쪽에서 모듈라 학습을 이용한 방법들에 대해서 상당한 관심이 모아지고 있다[11,12]. 분할 및 합병 개념에 바탕을 둔 모듈라 학습 방법이 복잡한 문제를 해결함에 있어서 학습 질 측면이나 학습 속도 면에서 단일 분류기에 비해 좋은 결과를 보이고 있고, 인공신경망을 이용한 분류 방법 쪽에서도 이러한 연구들[13,14,15,16]이 이루어지고 있다.

본 논문에서는 번호판 인식을 위한 간단한 형태의 모듈라 신경망을 제안하고 이의 성능을 평가하고자 한다. 일반적으로 모듈라 학습은 크게 두 단계로 이루어지는데, 첫 단계는 문제를 작은 문제로 분할하는 단계이며, 두 번째 단계는 분

접수일자 : 2003년 4월 10일

완료일자 : 2003년 7월 9일

감사의 글 : 본 연구는 2002년도 금오공과대학교 학술 연구비 지원에 의하여 연구된 논문임.

할된 문제를 별도의 분류기를 사용하여 학습하고 각 분류기의 결과를 통합하여 최종 결정을 내리는 단계이다. 모듈라 신경망을 구성 할 때 주어진 표준 벡터들을 클러스터링을 통하여 각 분류기를 구성을 하는데, 이 때 어떻게 구성하느냐에 따라 인식 결과가 달라진다. 본 논문에서는 대상 패턴을 몇 개의 그룹으로 나누고 이들 각각을 다층퍼셉트론을 사용하여 학습하는 방법을 선택한다. 대상 패턴을 나누는 방법은 K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터를 그룹핑하는 방법과 본 논문에서 제안한 알고리즘을 사용하여 유사하지 않는 특징 벡터들을 그룹핑하는 방법을 각각 사용한다.

본 논문의 구성은 2장에서는 번호판 인식을 위하여 제안한 클러스터링 방법에 따른 모듈라 신경망 구성 방법에 대해 소개하고 3장에서는 실험을 통한 검증을 4장에서는 결론 및 향후 연구 과제에 대해서 다룬다.

2. 관련 연구

자동차 번호판 문자 인식에 관한 연구는 크게 번호판 영역 추출 부분과 인식 부분으로 나뉜다. 번호판 영역을 추출하는 방법으로는 소벨 연산과 Hough 변환에 의한 방법[2,3], 명암도 변화를 이용한 방법[1], 단일 색상 정보에 의한 방법[4,5], 복합 색상 정보에 의한 방법[6] 등이 있다.

소벨 연산과 Hough 변환에 의한 방법[2,3]은 입력 영상에 대하여 이진화 후 Hough 변환을 사용해서 번호판의 수직선과 수평선을 찾아내는 방법이다. 수직, 수평 선 검출에는 효과적이지만 수평, 수직 성분을 정확히 추출하지 못하면 번호판 영역 추출이 불가능하다는 문제점을 가진다.

명암도 변화를 이용한 방법[1]은 차량 번호판 영역에서는 문자와 배경 사이의 명암도 변화의 차이가 크고 변동 회수도 다른 영역보다 많다는 번호판의 특성을 이용한다. 이 방법은 구현이 간단하고 잡음이 다소 첨가된 경우에도 추출이 가능하다.

단일 색상 정보에 의한 방법[4,5]은 추가적인 색상 정보를 활용하는 방법으로서 번호판 영역에서의 색상 정보가 다르다는 사전 지식을 이용한다. 빠른 처리 시간을 가지나 번호판과 유사한 색상이나 주변 밝기에 따라 추출률 변화가 심하다는 단점이 있다.

복합 색상 정보에 의한 방법[6]은 RGB 컬러 모델을 HSI 컬러 모델과 YIQ 컬러 모델로 변환하여 결합된 색상 정보를 이용하는 방법이다. RGB 값으로부터 HSI의 H 성분과 YIQ의 Q 성분을 추출하고, 각 성분을 0~255 구간으로 정규화한다. 그리고, 이진화 후 임계치에 의해 번호판 영역을 추출한다. 이 방법은 단일 색상 정보에 의한 방법만 사용했을 때보다 번호판과 유사한 색상이나 주변 밝기에 따른 영향을 덜 받는다.

문자 인식에 관한 선행된 연구는 추출된 영역으로부터의 개별 문자를 신경망을 이용한 방법[7,8,9]과 원형정합 알고리즘, 세션화 알고리즘, 벡터 알고리즘 등 여러 가지 알고리즘을 병행, 적용한 방법[10] 등이 있다

신경망을 이용한 방법[7,8,9]은 주어진 패턴을 가장 잘 표현할 수 있는 특징을 추출한 후 특징벡터를 만들고, 만들어진 특징벡터를 신경회로망 모델의 입력으로 사용하여 인식하는 특징 기반(Feature-based) 방법을 많이 사용한다[1,17]. 특히 이 때의 신경회로망의 모델은 ART2이다. 이러한 특징 기반 방법들은 적합하지 못하거나 잘못 선택된 특징들을 사

용하면 주어진 패턴에 대해 충분한 정보를 포함하지 못하게 되어 그 결과 인식을 저하를 초래한다.

알고리즘을 병행 적용한 방법[10]은 원형정합 방법을 사용하는데 각 문자별로 원형 문자를 만든다. 추출된 개별문자와 원형과 비교하기 위해서 추출된 개별 문자를 원형 크기로 정규화 한다. 이 방법은 알고리즘이 간단하고 인식 시간을 단축할 수 있으나 문자 추출시의 문자 이동이나 부분적 잘림 등에 의한 왜곡을 보정 할 수 없는 단점이 있다.

3. 번호판 인식을 위한 모듈라 신경망

3.1 신경망의 구조

모듈라 신경망의 구조는 여러 가지 형태가 있을 수 있지만 본 논문에서는 그림 1과 같은 간단한 형태를 선택하였다.




그림 1. 모듈라 다층 퍼셉트론 신경망 구조
Fig. 1. Modular neural network architecture

망의 구조는 세 계층 - 입력층, 국부층(Local Layer), 결정층(Decision Layer)으로 구성이 된다. 입력층은 획득 영상에서 전처리 과정을 통해 추출된 개별 문자의 특징 벡터가 입력되는 층이며, 국부층은 각 그룹의 패턴들을 학습 및 인식하는 층으로 패턴 그룹 수만큼의 다층퍼셉트론들로 구성되며, 각 다층퍼셉트론의 입력층 뉴런의 수는 특징 벡터의 차원과 같으며 출력층의 뉴런의 수는 각 서브네트워크가 담당하는 학습패턴의 수와 같다. 즉, 각 서브네트워크의 입력층 뉴런의 수는 동일하지만 출력층 뉴런의 수는 다르다. 결정층은 국부층에서 인식된 결과를 종합하여 최종 결정을 내리는 층이다.

3.2 학습 및 인식

학습은 그림 2처럼 국부층에 있는 모듈, 즉 서브네트워크 별로 해당 학습데이터를 다층퍼셉트론을 통하여 학습한다. 학습 방법은 기존의 다층퍼셉트론과 다를 바가 없다. 각 서브네트워크가 독립적으로 학습이 되기 때문에 재학습이 요구될 경우에는 해당 신경망만 재학습을 하면 된다.

패턴의 인식은 먼저 모든 서브네트워크에 동일한 테스트 데이터가 입력된다. 추출된 개별 문자 영역의 이미지가 특징 벡터로 만들어지고 모든 서브네트워크를 통해 입력된다. 그런 후 각 서브네트워크는 학습된 결과를 이용하여 각자의 결과를 출력하게 된다. 최종적으로 결정층에서 이들 결과를 종합하여 최종 인식 패턴을 결정하게 된다.




그림 2. 모듈라 신경망 학습 방법
Fig. 2. Learning method of modular neural network

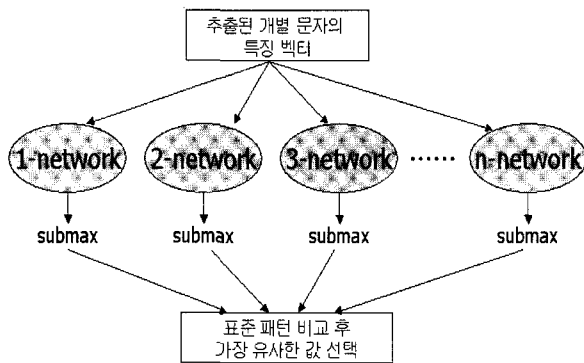


그림 3. 모듈라 신경망 인식 방법
Fig. 3. Recognition method of modular neural network

3.3 특징 벡터 구성 방법

일반적으로 패턴을 가장 잘 표현할 수 있는 특징을 추출하여 특징 벡터를 만들어야 번호판 인식에서 좋은 인식률을 볼 수 있다[10]. 하지만, 본 연구의 주제가 특징 벡터가 주어졌을 경우 어떻게 모듈라 신경망을 구성하는 것이 좋은가이기 때문에 본 논문에서는 그림 4와 같이 간단한 특징 벡터 구성 방법을 사용하였다.

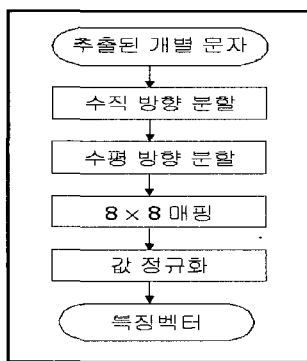


그림 4. 특징 벡터 추출 흐름도
Fig. 4. Flow chart of feature vectors extraction

본 논문에서 사용한 특징 벡터는 문자 영상을 이진화 한 후 1의 개수가 같도록 가변 그물눈을 생성한 후 각 블록 내에서의 1의 비율을 계산한 값을 사용하였다. 그물눈은 수평 방향으로 8분할하고 수직 방향으로 8분할하였다. 즉, 특징 벡터는 64차원 (8x8)이며 각 차원은 0과 1 사이의 값을 갖는다.

3.4 모듈 구성법

3.4.1 유사한 특징 벡터간의 그룹핑

첫 번째 방법은 그림 5와 같이 K-means 클러스터링 알고리즘을 이용하여 유사한 패턴 사이들을 그룹화 하는 방법이다. 사전에 결정된 그룹의 수 k에 기초하여 전체 데이터를 유사한 k개의 그룹으로 구분하는 방법이다.

- ① 첫 번째 단계에서 k개의 클러스터를 미리 정해놓고 각 패턴들을 랜덤하게 클러스터에 할당한다.
 - ② 두 번째 단계에서 그룹의 중심을 선택한다.
 - ③ 세 번째 단계에서 각 특징 벡터를 갖는 패턴(관찰치)을 그 중심과 가장 가까운 거리에 있는 그룹에 할당한다.
 - ④ 네 번째 각 그룹별로 그에 속하는 패턴(관찰치)을 이용해 새로운 중심을 계산한다.
- 위의 과정을 기존의 중심과 새로운 중심의 차이가 없을 때까지 반복한다.

그림 5. 유사한 특징 벡터간의 그룹핑
Fig. 5. Grouping similar feature vectors

표 1은 그룹의 수를 8로 했을 경우의 패턴 분할의 형태를 보여주고 있다.

표 1. 유사한 특징 패턴 그룹핑의 한 형태

Table 1. An example of grouping of similar feature vectors

그룹 1	노 소 구 수 느 스 2 3 5 6 7 9
그룹 2	하 강 경 광 남 산 원 인 전 천 0
그룹 3	파 루 후 북 울 중 1 4 8
그룹 4	나 누 두 무 부 우 주 추 쿠 투 푸
그룹 5	다 라 마 바 아 타 너 더 커 니 디 리 이 지 치 키 티
그룹 6	고 도 로 모 보 오 조 초 코 토 포 호 그 드 르 모 브 으 즈 츠 크 트 프 호
그룹 7	가 사 자 차 카 거 서 기 시
그룹 8	러 머 버 어 저 처 터 퍼 허 미 비 피 히 대 제

3.4.2 제안한 유사하지 않은 특징 벡터간의 그룹핑

유사하지 않은 패턴들을 그룹화하기 위해 그림 6과 같은 변형된 K-means 클러스터링 알고리즘을 사용하였다.

- ① k개의 클러스터를 미리 정해놓고 각 패턴들을 랜덤하게 클러스터에 할당한다.
- ② 임의의 패턴과 각 그룹과의 거리를 구한다. (단, 거리는 그룹에 속한 패턴 중 가장 가까운 패턴과의 거리)
- ③ 가장 먼 그룹에 임의의 패턴을 할당한다. 단, 임의의 패턴이 원래 속해 있던 그룹에 다른 패턴이 존재하지 않을 경우, 즉, 원소의 수가 1인 경우는 새로운 그룹에 할당하지 않는다.
- ④ ②~③과정을 패턴이 속한 그룹이 차이가 없을 때까지 반복한다.

그림 6. 유사하지 않은 특징 벡터간의 그룹핑
Fig. 6. Grouping unsimilar feature vectors

그림 7은 K=2일 때 유사하지 않은 패턴 사이에 클러스터링을 보여준다.

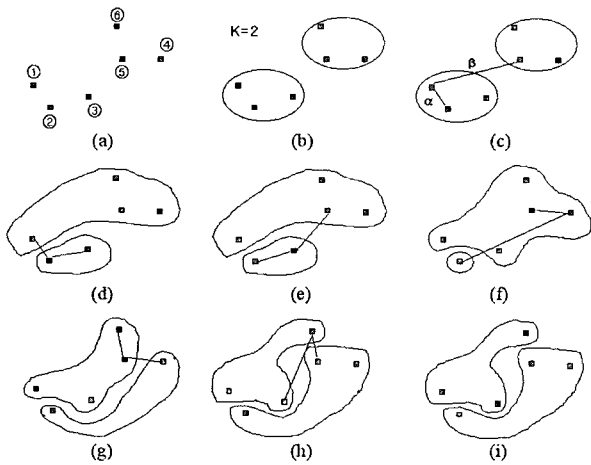


그림 7. K=2 일 때 클러스터링의 예
Fig. 7. Example of clustering given K=2

(a)와 같이 초기 패턴들이 주어지고 클러스터의 수가 2라고 하자. 그러면, (b)에서와 같이 각 패턴들은 랜덤하게 클러스터에 할당된다. (c)에서 임의의 패턴 ①과 각 그룹과의 거리를 구한다. 이때 임의의 패턴 ①과 각 그룹에서 가장 가까운 패턴과의 거리를 구한다. 그림 7 (c)에서는 특징 패턴 ①과 각 그룹과의 가장 가까운 패턴 ②와 ⑤의 거리 α , β 를 구하게 된다. 각 그룹과의 거리를 구한 다음 가장 먼 그룹에 임의의 패턴을 할당한다. 그림 7 (d)처럼 β 의 거리를 갖는 ⑤ 패턴이 속한 그룹에 임의의 패턴 ①이 할당된다. 그리고 그림 7 (f)처럼 임의의 패턴이 원래 속해 있던 그룹에 다른 패턴이 존재하지 않을 경우, 즉, 원소의 수가 1인 경우는 새로운 그룹에 할당하지 않는다. 또 다른 임의의 패턴을 선택 후 같은 과정을 패턴이 속한 그룹이 차이가 없을 때까지 반복한다.

표 2는 제안한 방법에 따른 특징 벡터간의 그룹핑에서 그룹의 수를 8로 했을 경우의 패턴 분할의 형태를 보여주고 있다.

표 2. 유사하지 않은 특징 패턴 그룹핑의 한 형태

Table 2. An example of grouping of unsimilar feature vectors

그룹 1	무 바 부 북 비 산 수 자 천 터 호
그룹 2	강 도 디 루 버 브 사 으 처 추 키 토 파 프
그룹 3	7 9 고 누 다 두 드 리 서 소 원 초 카 퍼
그룹 4	5 경 기 나 로 오 우 이 인 티 하 허 후 호
그룹 5	6 거 느 러 미 보 시 아 제 조 주 충 츠
그룹 6	1 2 4 8 광 노 더 르 차 커 크 타 포 푸 피
그룹 7	0 가 구 그 너 라 머 모 무 울 저 전 즈 치 투
그룹 8	3 남 니 대 마 스 어 지 코 쿠 트 히

3.5 결정층 구성

모듈라 신경망의 세 계층 중 결정층은 국부층에서 인식된 결과를 종합하여 최종 인식 패턴을 결정하는 층이다. 결정층에서 어떤 방법을 사용하느냐에 따라 인식률에 영향을 미친다.

본 논문에서는 결정층 구성 방법을 국부층 출력값 중 최대값을 선택하는 방법, 국부층 출력 뉴런의 값에 출력 뉴런에 해당하는 표준패턴과 입력 패턴 사이의 유사도 값을 곱한 값 중 최대값을 선택하는 방법, 그리고 국부층 출력값의 표준 벡터들과 입력 패턴을 비교하여 가장 유사한 값을 선택하는 방법을 이용하였다. 즉, 이를 간략히 표시하면 아래와 같다.

$$\text{Max}_{1 \leq i \leq n} P_{s_i} \quad (1)$$

$$\text{Max}_{1 \leq i \leq n} O(P_{s_i}) * S(P_{s_i}, I) \quad (2)$$

$$\text{Max}_{1 \leq i \leq n} S(P_{s_i}, I) \quad (3)$$

여기서 n 은 서브네트워크의 개수이고 P_{s_i} 는 서브네트워크 s_i 에서 입력 I 에 대해 최대 출력값을 보이는 노드의 패턴이다. $O(P_{s_i})$ 는 패턴 P_{s_i} 의 출력값을, $S(P_{s_i}, I)$ 는 입력 I 와 패턴 P_{s_i} 의 표준벡터와의 유사도로 본 논문에서는 유사도 측정 함수로 유클리디안 거리를 사용하였다.

위의 수식에서 보는 바와 같이, 첫 번째 방법은 국부층 출력값 중 최대값을 선택하는 방법으로 각 서브네트워크들의 출력 뉴런의 값 중에서 가장 큰 값을 선택하는 방법이다. 두 번째 방법은 각 서브네트워크들의 출력 뉴런의 값 중 가장 큰 값을 선택하고, 출력 뉴런에 해당하는 표준벡터와 입력 패턴 사이의 유사도 값을 곱한 값 중 최대값을 선택하는 방법이다. 그리고, 세 번째 방법은 국부층 출력값의 표준 벡터들과 입력 패턴을 비교하여 가장 유사한 값을 선택하는 방법으로 먼저 각 서브네트워크의 출력 뉴런 중에서 가장 큰 값을 선택하고 이에 해당하는 패턴들의 표준 벡터들과 입력 패턴을 비교하여 가장 가까운 것으로 판단한다.

4. 실험 및 결과

4.1 실험 데이터

번호판 영역 추출 시 기존의 연구 방법 중 하나인 칼라 명암도 변화를 이용한 방법[1]과 HSI 색상 정보를 이용한 방법




그림 8. 차량 영상에서의 번호 추출 예
Fig. 8. An example of character extraction from a sample image

[19]을 사용하여 번호판 영역을 추출하고 번호판 영역 상단부와 하단부를 분리한 다음 히스토그램을 적용하여 개별 문자를 추출한다.

그림 8에서 (a)는 신경망 학습을 위한 조작해서 만든 샘플 데이터의 한 예를, 그림 (b)는 본 실험에서 사용한 차량 이미지의 한 예를, (c)는 (b)로부터 번호판 영역을 추출한 그림이며, (d)는 (c)로부터 추출한 개별문자의 예를 보여주고 있다.

4.2 비모듈라 신경망과의 비교

모듈라 신경망과 그렇지 않은 방법의 인식 성능을 비교하기 위해 위에서 신경망 학습을 위한 데이터는 Adobe Photoshop 6.0에서 차량번호와 가장 유사한 hygdic-extra 폰트를 조작해서 만든 크기 60×60 샘플 데이터 108개와 번호판 영상에서 추출한 106개를 사용하였으며, 차량 번호판으로부터 얻은 별도의 데이터 1196개를 실제 테스트 데이터로 사용하였다. 결정층에서 사용되는 표준 패턴은 학습 시에 사용한 데이터들의 중심벡터로 하였다. 즉, 한 패턴에 대해 여러 개의 학습 데이터가 존재하는데, 이때 이 패턴의 표준 패턴은 해당 학습 데이터의 중심으로 하였다.

모듈라 신경망은 K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터를 그룹핑하고 8개의 그룹으로 구성을 하였으며 각 다층퍼셉트론 학습 시 이득함은 0.9로, 모멘텀함은 0.2로 하였다.

테스트 방법은 재학습의 성능도 같이 평가하기 위해 전체 테스트 데이터를 한번에 테스트하지 않고 117개, 420개, 479개, 180개의 네 그룹으로 나누어 테스트하였다. 즉, 117개의 데이터를 테스트 한 후 오인식된 패턴을 재학습시키고 그 결과를 이용하여 420개의 데이터에 대해서 평가하는 식으로 진행하였다. 테스트 데이터를 나눈 기준은 특별한 이유가 없으며 단지 영상 획득 시기가 달라서 편의상 그렇게 나누었다.

표 3은 단일 다층퍼셉트론을 사용했을 경우의 성능이며, 표 4는 8개의 다층퍼셉트론으로 구성된 모듈라 신경망의 성능을 나타낸다. 표에서 보는 바와 같이 모듈라 신경망이 그렇지 않은 방법에 비해 문자인식에서 우수한 결과를 보였으며 훈련 반복횟수가 증가할 수록 좋은 인식률이 보였다.

표 3. 단일 신경망의 인식률

Table 3. Recognition rate of singular neural network

구분 훈련수	총 테스트 패턴 수	인식 패턴 수	인식 실패	재학습 패턴 수	인식률
1	117	82	35	35	70.0 %
2	420	288	132	41	68.6 %
3	479	317	162	52	66.1 %
최종 테스트	180	131	49		72.8 %

표 4. 모듈라 신경망의 인식률

Table 4. Recognition rate of modular neural network

구분 훈련수	총 테스트 패턴 수	인식 패턴 수	인식 실패	재학습 패턴 수	인식률
1	117	89	28	28	76.1 %
2	420	347	73	23	82.6 %
3	479	447	32	14	93.3 %
최종 테스트	180	177	3		98.3 %

4.3 클러스터링 방법에 따른 성능 비교

특징 벡터 클러스터링 방법에 따라 모듈라 신경망의 성능을 평가하기 위해 차량번호와 가장 유사한 hygdic-extra 폰트를 조작해서 만든 크기 60×60 샘플 데이터 108개를 학습 데이터로 사용하였으며, 차량 번호판으로부터 얻은 별도의 데이터 423개를 실제 테스트 데이터로 사용하였다. 모듈라 신경망의 결정층에서 사용되는 표준 패턴은 학습 시에 사용한 데이터들의 중심벡터로 하였다. 즉, 한 패턴에 대해 여러 개의 학습 데이터가 존재하는데, 이때 이 패턴의 표준 패턴은 해당 학습 데이터의 중심으로 하였다.

실험에 사용한 모듈라 네트워크는 2개의 그룹부터 10개의 그룹으로 구성하면서 사용하였다. 각 다층퍼셉트론 학습 시 이득함은 0.9로, 모멘텀함은 0.2로 하였다.

표 5는 K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터들을 그룹핑한 경우의 성능과 제한한 클러스터링 방법에 따라 유사하지 않은 특징 벡터들을 그룹핑한 경우의 모듈라 신경망의 성능을 보여주고 있다. 초기 학습 후 테스트 한 결과이며, 그룹의 수가 1부터 4인 경우 성능이 0%인 것은 수렴에 실패하고 지역 최소값에 봉착한 것이다. 유사한 특징 벡터 그룹핑 시에는 그룹의 수가 8일 경우 성능이 좋았으며, 유사하지 않은 특징 벡터를 그룹핑 할 시는 그룹의 수가 5일 때가 가장 좋았다.

표 5. 클러스터링 방법에 따른 성능 비교

Table 5. Performance comparison of clustering method

그룹수 방법	4	5	6	7	8	9	10
유사한 그룹핑	0%	52.2%	58.3%	49.1%	58.4%	51.5%	40.4%
유사하지 않은 그룹핑	41.1%	69.0%	64.3%	59.3%	63.5%	38.0%	49.6%

추가로, 재학습을 통한 각각의 모듈라 신경망의 성능을 비교하였다. 테스트 방법은 차량 번호판으로부터 얻은 전체 데이터 885개를 214개, 215개, 236개, 220개의 네 그룹으로 나누어 테스트하였으며, 각 다층퍼셉트론 학습 시 이득함은 0.9, 모멘텀함은 0.2로 하였다.

표 5를 보면 유사한 그룹핑 방법에서 그룹수 8일 때의 인식률이 좋았으며, 유사하지 않은 그룹핑 방법에서는 그룹수 5일 때 인식률이 좋았다. 따라서 [18]에서 사용한 방법과 제한한 방법으로 구성된 모듈라 신경망의 성능을 비교하기 위하여 각각 좋은 인식률을 보인 그룹수 8과 5일 때를 동일한 조건으로 테스트를 하였다. [18]에서 사용한 방법은 3.4.1에서 기술한 K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터를 그룹핑하여 구성된 모듈라 신경망의 방법을 말한다.

표 6은 유사한 특징 벡터들로 구성된 8개의 다층퍼셉트론으로 이루어진 모듈라 신경망의 성능을 나타내고, 표 7은 유사하지 않은 특징 벡터들로 구성된 5개의 다층퍼셉트론으로 이루어진 모듈라 신경망의 성능을 나타낸다.

표 6, 7에서 보는 바와 같이 제한한 방법으로 서브네트워크를 구성한 모듈라 신경망이 기존 방법에 비해 문자인식에서 좋은 결과를 보였으며 훈련 반복횟수가 증가할 수록 좋은 인식률을 보였다.

표 6. [18]에서 사용한 방법으로 구성된 모듈라 신경망의 인식률

Table 6. Recognition rate of the modular neural network constructed by the clustering method used in [18]

구분 훈련수	총 테스트 패턴 수	인식 패턴 수	인식 실패	재학습 패턴 수	인식률
1	214	163	51	9	76.1 %
2	215	177	38	11	82.3 %
3	236	220	16	7	93.2 %
최종 테스트	220	212	8		96.3 %

표 7. 제안된 방법으로 구성된 모듈라 신경망의 인식률

Table 7. Recognition rate of the modular neural network constructed by the proposed clustering method

구분 훈련수	총 테스트 패턴 수	인식 패턴 수	인식 실패	재학습 패턴 수	인식률
1	214	181	33	7	84.5 %
2	215	187	28	11	87.3 %
3	236	225	11	5	95.3 %
최종테스트	220	214	6		97.2 %

4.4 결정층 구성 방법에 따른 성능 비교

결정층 구성 방법에 따른 성능 비교를 위하여 제안한 방법인 클러스터링 방법에 따라 유사하지 않은 특징 벡터들을 그룹핑한 경우의 모듈라 신경망을 구성하고 차량 번호판으로부터 얻은 전체 데이터 885개를 214개, 215개, 236개, 220개의 네 그룹으로 나누어 테스트하였으며, 각 다층퍼셉트론 학습 시 이득함은 0.9, 모멘텀함은 0.2로 하였다. 결정층에서 어떤 방법을 사용하느냐에 따라 인식률에 영향을 미친다. 본 논문에서는 결정층 구성 방법을 국부층 출력값 중 최대값을 선택하는 방법, 국부층 출력 뉴런의 값에 출력 뉴런에 해당하는 표준패턴과 입력 패턴 사이의 유사도 값을 곱한 값 중 최대값을 선택하는 방법, 그리고 국부층 출력값의 표준 벡터들과 입력 패턴을 비교하여 가장 유사한 값을 선택하는 방법을 각각 테스트하였다.

아래 표 8은 결정층 구성 방법에 따라 인식률을 보여준다.

표 8. 결정층 구성 방법에 따른 인식률
Table 8. Recognition rates of decision logics

		첫 번째 방법	두 번째 방법	세 번째 방법
1차 테스트	테스트 패턴 수	214	214	214
	인식 성공	165	174	181
	인식률	77.1%	81.3%	84.5%
2차 테스트	테스트 패턴 수	215	215	215
	인식 성공	174	183	187
	인식률	80.9%	85.1%	87.3%
3차 테스트	테스트 패턴 수	236	236	236
	인식 성공	207	219	225
	인식률	87.7%	92.7%	95.3%
최종 테스트	테스트 패턴 수	220	220	220
	인식 성공	201	210	214
	인식률	91.3%	95.4%	97.2%

국부층 출력값 중 최대값을 선택하는 방법과 국부층 출력 뉴런의 값에 출력 뉴런에 해당하는 표준패턴과 입력 패턴 사이의 유사도 값을 곱한 값 중 최대값을 선택하는 방법 보다 국부층 출력값의 표준 벡터들과 입력 패턴을 비교하여 가장 유사한 값을 선택하는 방법이 다른 방법보다 좋은 결과를 얻었다. 이러한 이유는 주어진 입력 패턴이 해당 서브네트워크에서는 최고의 출력값을 가질 지라도 다른 서브네트워크에서 인식한 패턴의 출력값 보다 작을 수가 있기 때문이다. 따라서 두 번째 방법과 세 번째 방법처럼 각 서브네트워크에서 인식한 패턴들에 대해서 별도로 표준패턴과 비교하여야 좋은 인식률을 볼 수 있다.

5. 결론 및 향후과제

본 논문에서 획득된 차량 영상에서 개별 문자가 추출되고 특징 벡터를 구한 다음 문자 인식을 위해서 신경망 이용 모듈라 신경망을 통하여 인식하는 방법을 사용하였다. 그리고 모듈라 신경망을 구성 시, 특징 벡터 사이에 클러스터링 방법에 따라 모듈라 신경망의 성능을 평가하였다. K-means 클러스터링 알고리즘을 이용하여 유사한 특징 벡터를 그룹핑한 경우 보다 제안한 클러스터링 방법에 따라 유사하지 않은 특징 벡터를 그룹핑 한 경우가 인식을 면에서 더 좋은 성능을 보였다. 또한, 인식을 측면뿐만 아니라 학습 속도 면에서도 상당한 이득이 있었다. 이러한 점은 실용적 측면에서 많은 도움이 되리라 생각된다.

차후, 모듈라 신경망의 구조에 대한 연구가 필요하며 현재 사용하는 결정층의 최종 판단 방법을 달리하여 실험해 볼 필요도 있다. 또한, 현재는 간단한 전처리 과정만을 거쳤는데 보다 실용적인 시스템을 구축하기 위해서는 질이 좋지 않은 영상에서 개별문자를 추출하는 연구나 특징 추출에 대한 연구가 필요하다.

참고 문헌

- [1] 서창진, 육창근, 강명호, 차의영, "자동차 번호판 영역에서의 문자추출과 신경회로망을 이용한 문자인식," 한국정보처리학회 춘계 학술발표 논문집, pp.1101-1104, 1997.
- [2] D.H. Ballard, Computer Vision, Prentice-Hall, Inc. pp76-79, 1991.
- [3] 정효식, 조형제, "분할된 영역의 특성을 이용한 차량 번호판 포착," 한국정보과학회 논문지, 제21권 제6호, pp.1149-1159, 1994.
- [4] M. R. Fairchild, Color Appearance Model, Wesley, 1998.
- [5] 김병기, "명암변화와 칼라정보를 이용한 차량 번호판 인식," 한국정보처리학회 논문지 A, VOL. 06, NO. 12 pp. 3683-3693, 1999. 12.
- [6] 이화진, 박형철, 전병환, "HSI와 YIQ의 복합 색상정보를 이용한 차량 번호판 영역 추출," 한국정보처리학회 논문지 A, VOL. 07, NO. 12, pp. 3995-4003, 2000. 12.
- [7] 조보호, 정성환, "ART2 신경회로망을 이용한 차량 번호판 문자 인식," 한국정보과학회, '97 가을 학술발표 논문집(2), pp. 455-458, 1997, 10.

[8] 김도형, 이선화, 김미숙, 차의영, "자동차 번호판 영역의 문자추출과 인식에 관한 연구," 정보과학회 2000년 추계학술대회, VOL. 27, NO. 02, pp. 0338-0340, 2000. 10.

[9] 강동구, 김도형, 최선아, 차의영, "모폴로지와 ART2를 이용한 번호판 위치 검출 및 문자 세그멘테이션에 관한 연구," 정보과학회 2001년 추계학술대회, VOL. 28, NO. 02, pp. 0328-0330, 2001. 10.

[10] 이용주, "수직 및 수평 명암도 변화값과 원형 패턴 벡터를 이용한 차량번호판 추출 및 인식 알고리즘," 한국정보처리학회 논문지 B, VOL. 8-B, NO. 02, pp. 0195-0200, 2001. 04.

[11] Shailesh Kumar, Joydeep Ghosh, Melba M. Crawford, "Hierarchical Fusion of Multiple Classifiers for Hyperspectral Data Analysis," Pattern Analysis & Applications Volume 5, Issue 2, pp 210-220, 2002.

[12] Sushmita Mitra, Pabitra Mitra, Sankar K. Pal, "Evolutionary Modular Design of Rough Knowledge-based Network using Fuzzy Attributes," Neurocomputing, Vol. 36, pp 45-66, 2001.

[13] Ballard D., "Modular learning in neural networks," Proc AAAI-87, pp. 279-284, 1987.

[14] Happel BLM, Murre JMJ., "Design and evolution of modular neural network architectures," Neural Network, Vol. 7 pp. 985-1004, 1994.

[15] Ramamurti V, Chosh J., "Structurally adaptive modular networks for nonstationary environments," IEEE Trans Neural Network, Vol. 10, pp. 152-160, 1999.

[16] Petridis V, Kehagias A., "Predictive Modular Neural Networks," Applications to Time Series. Kluwer Academic, Boston, 1998.

[17] 이진배, "조명과 기울기에 강한 차량번호판 인식에 관한 연구," 숭실대학교 석사 학위논문, 1995. 6.

[18] 박창석, 김병만, 이광호, 최조천, 오득환, "모듈라 신경망을 이용한 자동차 번호판 문자인식," 한국정보과학회, 가을학술발표 논문집, Vol. 29, No. 2, pp. 568-570, 2002, 10.

[19] Fafael C. Gonzalez and Richard E. Woods, Digital Image Processing, Addison Wesley, 1993.

저 자 소 개



박창석 (Chang Seok Park)

2002년 : 대구대학교 컴퓨터정보공학부 졸업.

2002년~현재 : 금오공과대학교 소프트웨어공학과 석사과정

관심분야 : 패턴인식,
E-mail : icisl@se.kur



김병만 (Byeong Ma)

1987년 : 서울대학교

1989년 : 한국과학기술원 석사

1992년 : 한국과학기술공학박사

1992년~현재 : 금오공과대학교 컴퓨터공학부 부교수

1998년~1999년 : 미국 Univ. of California, Irvine Post Doc.

관심분야 : 인공지능, 정보검색, 소프트웨어 검증
E-mail : bmkim@se.kumoh.ac.kr



서병훈 (Byung Hoo)

2003년 : 금오공과대학교 소프트웨어공학 석사

2003년~현재 : 금오공과대학교 석사과정

관심분야 : 패턴인식, 인공지능
E-mail : seozzang@se.kumoh.ac.kr



이광호 (KwangHo Lee)

1987년 : 서울대학교 컴퓨터공학과 학사

1989년 : 한국과학기술원 전산학과 공학 석사

1996년 : 한국과학기술원 전산학과 컴퓨터공학박사

1996년~현재 : 목포대학교 컴퓨터교육과 부교수

관심분야 : 영상처리, 인공지능
E-mail : klee@ai.mokpo.ac.kr